

PREVISÕES HÍBRIDAS DE DESLOCAMENTO HORIZONTAL DE BLOCO EM BARRAGEM DE USINA HIDRELÉTRICA

JAIRO MARLON CORRÊA*, LUIZ ALBINO TEIXEIRA JÚNIOR†, EDGAR MANUEL CARRENO FRANCO‡, SAMUEL BELLIDO RODRIGUES*, TÁSIA HICKMANN*

* *Universidade Tecnológica Federal do Paraná
Medianeira, Paraná, Brasil*

† *Universidade Federal da Integração Latino-Americana
Foz do Iguaçu, Paraná, Brasil*

‡ *Universidade Estadual do Oeste do Paraná
Cascavel, Paraná, Brasil*

Emails: jairocorrea@utfpr.edu.br, luiz.a.t.junior@gmail.com, emfra.unioeste@gmail.com, samuelb@utfpr.edu.br, hickmann@utfpr.edu.br

Abstract— This paper presents a hybrid methodology called WARIMAX-GARCH Neural (WAXGN) whose objective is to generate forecasts for a time series of displacement measurement of a block of Itaipu Hydroelectric Power Plant, located in Foz do Iguaçu, Paraná, Brazil. In general, the WAXGN method is divided into four steps: (1) makes up a wavelet decomposition level p of the aforesaid time series to produce $p + 1$ Wavelet components (CWS); (2) Each step of the CW (1) is shaped by an artificial neural network (ANN), in order to generate predictions outside the sample; (3) CWs of step 1 are supplemented by the respective predictions, obtained in (2), by generating artificial exogenous variables Wavelet-neural; and (4) is made modeling the temporal offset via a series ARIMAX-GARCH exogenous variables which are generated in step (3). In all analyzes considered the methodology WAXGN obtained greater accuracy in predictive terms out of the sample.

Keywords— Forecast, wavelet decomposition, ARIMA-GARCH Models, Artificial Neural Networks.

Resumo— Neste artigo é apresentada uma metodologia híbrida chamada de WARIMAX-GARCH Neural (WAXGN) cujo objetivo é gerar previsões para uma série temporal de medições de deslocamento de um bloco da Usina Hidrelétrica de Itaipu, localizada em Foz do Iguaçu, Paraná, Brasil. Em linhas gerais, o método WAXGN é dividido em quatro passos: (1) faz-se uma decomposição Wavelet de nível p da série temporal supracitada, de forma a produzir $p + 1$ componentes Wavelet (CWs); (2) cada CW do passo (1) é modelada por uma rede neural artificial (RNA), a fim de se gerar previsões fora da amostra; (3) As CWs do passo 1 são completadas pelas respectivas previsões, obtidas em (2), gerando-se as variáveis exógenas artificiais Wavelet-Neural; e (4) é feita a modelagem da série temporal deslocamento por meio de um modelo ARIMAX-GARCH cujas variáveis exógenas são as geradas no passo (3). Em todas as análises consideradas, a metodologia WAXGN obteve maior acurácia em termos preditivos fora da amostra.

Palavras-chave— Previsão, Decomposição Wavelet, Modelos ARIMAX-GARCH, Redes Neurais Artificiais.

1 Introdução

Desde os primórdios das civilizações, o uso da energia hidráulica teve importância devido à disponibilidade de recursos, facilidade de aproveitamento e, especialmente, seu caráter renovável. A energia hidráulica representa cerca de 20%, atualmente, de toda a eletricidade gerada no planeta. Das fontes renováveis é considerada a de maior representatividade na matriz energética mundial por possuir tecnologias aprimoradas em produção de energia elétrica, basta considerar as usinas hidrelétricas já construídas.

A usina hidrelétrica de Itaipu é resultado dos esforços e do comprometimento de dois países vizinhos, Brasil e Paraguai, cuja origem das negociações ocorreu a partir de 1966 e na sequência foi criado o "Tratado de Itaipu". A Itaipu Binacional é um dos maiores projetos hidrelétricos do mundo, considerando-se a produção anual. Localiza-se no rio Paraná a 14 km à montante da ponte internacional que liga a cidade de Foz do Iguaçu, no

Brasil, à Ciudad del Este no Paraguai.

A usina de Itaipu foi concebida com um plano de auscultação que conta com mais de 2400 instrumentos e um sistema de drenagem com mais de 5000 drenos, instalados em suas estruturas e fundações, formando um banco de dados de mais de 30 anos. Alguns blocos são designados blocos chave, pois são dotados de maior quantidade de instrumentos devido a sua importância para a região monitorada e características pré-definidas em projeto.

Em 2005, como parte de modernização da usina, foi implantado um sistema de aquisição de dados automáticos (ADAS), onde 10% dos instrumentos mais importantes foram automatizados, passando a ter leituras a cada 30 minutos, além da leitura manual já existente.

De acordo com (Binacional, 2009), foram instalados dois tipos de pêndulos instalados em trechos da Usina Hidrelétrica de Itaipu: o pêndulo direto e o invertido. A análise dos dados dos pêndulos mostra que o deslocamento descreve um mo-

vimento que gera uma curva cujo comportamento é cíclico, influenciado pela temperatura ambiente.

Neste estudo, avalia-se a implementação de um modelo por meio do qual seja possível realizar a análise e a previsão do comportamento de um bloco da estrutura da barragem. Tais informações permitirão medidas corretivas em planos de execução e/ou tomada de decisões já existentes. É proposta uma metodologia híbrida chamada de WARIMAX-GARCH Neural (WAXGN) cujo objetivo é gerar previsões pontuais e intervalares para uma série temporal de deslocamento de um bloco da Usina Hidrelétrica de Itaipu.

2 Revisão de Literatura

2.1 Análise Wavelet

Na Análise Wavelet, uma série temporal, $f(\cdot)$ é, de forma ortogonal, decomposta, simultaneamente, a partir de informações de escala e de translação capturadas a partir de um conjunto $\{\omega_{m,n}(\cdot)\}_{(m,n) \in \mathbb{Z}^2}$ de funções Wavelet, onde $\omega_{m,n}(\cdot) := 2^{\frac{m}{2}} \omega(2^m(\cdot) - n)$ é gerado por meio da dilatação (associada ao parâmetro m) e translação (associada ao parâmetro n) de uma função Wavelet $\omega(\cdot)$ original (Levan and Kubrusly, 2003); (Júnior, 2013). Segundo (Mallat, 2008), o parâmetro m é chamado de parâmetro de escala diádica e n , de parâmetro de translação unitária.

Definições mais formais e gerais, do ponto de vista matemático, podem ser verificadas em (Júnior, 2013). As famílias de bases ortonormais Wavelet, em geral, são geradas por convoluções de $\omega(\cdot)$ e $\phi(\cdot)$. Em particular, as bases de Haar, Daubechies, Coiflet e Symlet são exemplos de famílias que, frequentemente, são utilizadas na modelagem de séries temporais, para fins de geração de previsões.

Baseado em (Kubrusly and Levan, 2006); (Mallat, 2008), tem-se que a decomposição Wavelet de uma série temporal $f(\cdot)$ é dada, genericamente, em (1).

$$f(\cdot) = f_{A_{m_0}}(\cdot) + \sum_{m=m_0}^{\infty} f_{D_m}(\cdot), \quad (1)$$

onde: $f_{A_{m_0}}(\cdot) := \sum_{n \in \mathbb{Z}} a_{m_0,n} \phi_{m_0,n}(\cdot)$ é a componente de aproximação de nível m_0 de $f(\cdot)$; $f_{D_m} := \sum_{n \in \mathbb{Z}} d_{m,n} \omega_{m,n}(\cdot)$ é a componente de detalhe de nível m de $f(\cdot)$; $d_{m,n}$ e $a_{m_0,n}$ são, respectivamente, os coeficientes de detalhe e de aproximação e são calculados, ainda nesta ordem, a partir do produto interno usual entre $f(\cdot)$ e $\omega_{m,n}(\cdot)$ (isto é, $d_{m,n} := \sum_{t=1}^T f(t) \omega_{m,n}(t)$) e entre $f(\cdot)$ e $\phi_{m_0,n}(\cdot)$ (isto é, $a_{m_0,n} := \sum_{t=1}^T f(t) \phi_{m_0,n}(t)$) para todo $m_0, m, n \in \mathbb{Z}$.

Na prática, é usual que o parâmetro m_0 tome valor igual ao nível de decomposição r (isto é, truncamento na r -ésima componentes de aproximação).

2.2 Redes Neurais Artificiais

De acordo com (Haykin, 2001), as redes neurais artificiais são sistemas paralelos distribuídos e compostos por unidades de processamento simples, denominadas neurônios artificiais, e dispostas em uma ou mais camadas interligadas por um grande número de conexões (sinapses), geralmente, unidirecionais (*feedforward*) e com pesos sinápticos para ponderação das entradas recebidas por cada neurônio.

O principal algoritmo de treinamento de redes neurais artificiais é o *backpropagation*, cujo ajuste dos pesos sinápticos ocorre por meio de um processo de otimização realizado em duas fases: *forward* e *backward* (Haykin, 2001).

A previsão de valores futuros de uma série temporal, por meio de uma RNA, inicia-se com a montagem do conjunto de padrões de treinamento (pares entrada/saída), o qual depende da definição do tamanho da janela L de tempo (para os valores passados da própria série temporal que se deseja prever e para as variáveis explicativas) e do horizonte de previsão h . Em um processo autoregressivo (linear ou não linear), o padrão de entrada é formado pelos valores passados da própria série que se deseja prever.

Por sua vez, o padrão de saída desejada é o valor da observação da série temporal no horizonte de previsão. Maiores detalhes, ver (Haykin, 2001).

2.3 Modelo WARIMAX-GARCH Neural

Seja y_t ($t = 1, \dots, T$) uma série temporal estacionária que exibe estrutura de autodependência linear. Também, assuma que $\left((x_{1,t})_{t=1}^T, \dots, (x_{(r+1),t})_{t=1}^T\right)$ denote uma lista de $(r+1)$ vetores de realizações de $(r+1)$ variáveis endógenas (estacionárias) da série temporal y_t ($t = 1, \dots, T$). Com base em (Box and Tiao, 1975); (Hamilton, 1994), cada realização y_t pode ser representada por um modelo ARIMAX (p, d, q), de acordo com:

$$\nabla^d y_t = \phi_0 + \sum_{j=1}^p \phi_j y_{t-j} + \sum_{i=0}^q \theta_i e_{t-i} + \sum_{i=1}^{r+1} \sum_{l_i=0}^{L_i} \alpha_{il_i} x_{i,t-l_i} + e_t, \quad (2)$$

onde: B é o operador de atraso definido por $B^k y_t := y_{t-k}$, onde k pertence a $\mathbb{Z}$; $\nabla^d := (1 - B)^d$ é o operador diferença, onde d é a ordem da diferenciação; $(\phi_j)_{j=1}^p$ e $(\theta_i)_{i=0}^q$ são listas

ordenadas de parâmetros complexos do modelo, com $\phi_p \neq 0$ e $\theta_q \neq 0$, e $(\alpha_{il_i})_{l_i=0}^{L_i}$ é o i -ésimo vetor de parâmetros complexo associado à componente causal; e_t é uma inovação no tempo t que consiste em uma realização de uma variável aleatória ε_t , onde y_t ($t = 1, \dots, T$) é um processo estocástico com média zero e covariância constante; e p e q são, respectivamente, as ordens da parte autorregressivas $\sum_{j=1}^p \phi_j y_{t-j}$ (notação: AR(p)) e da parte de médias móveis $\sum_{i=0}^q \theta_i e_{t-i}$ (notação: (MA(q))).

L_i é a ordem máxima do lag em $\sum_{l_i=0}^{L_i} \alpha_{il_i} x_{i,t-l_i}$ da variável exógena $x_{i,t}$, onde $i = 1, \dots, (r+1)$.

Em alguns casos a heteroscedasticidade pode depender dos valores observados do passado da série temporal ou de valores passados da sua variância, de tal modo que um modelo AR, bem como suas extensões, pode ser adaptado para projetar a variação temporal. Um modelo vastamente utilizado em sua modelagem é o chamado o Heteroscedasticidade Condicional Autorregressiva (GARCH). Segundo (Bollerslev, 1986), O modelo geral GARCH (P, Q) para a variância condicional σ_t^2 de inovações ε_t é dado por:

$$h(\sigma_t^2) = \gamma_0 + \sum_{j=1}^P \gamma_j \sigma_{t-j}^2 + \sum_{i=1}^Q \delta_i e_t^2, \quad (3)$$

com as seguintes restrições: $\sum_{j=1}^P \gamma_j + \sum_{i=1}^Q \delta_i < 1$; $\gamma_0 > 0$; $\gamma_j \geq 0$ ($j = 1, \dots, P$) e $\delta_i \geq 0$ ($i = 1, \dots, Q$).

Um modelo composto por (2) e (3), que representa as restrições acima mencionadas, é chamado de modelo WARIMAX-GARCH Neural (WAXGN). Assim, para se obter o melhor modelo WARIMAX-GARCH Neural possível, três passos básicos deverão ser levados em conta: (i) testar os valores dos parâmetros plausíveis p, d, q, I, L_i , em (2), bem como os parâmetros P e Q , em (3); (ii) definir o método para ser usado na estimação dos parâmetros do modelo WARIMAX-GARCH Neural; e, (iii) fazer um teste de diagnóstico para escolher o modelo mais parcimonioso e adequado a ser usado para gerar t previsões de nível de y_t ($t = 1, \dots, T$), bem como de sua variância.

3 Experimento Computacional

Nesta seção, os principais resultados de uma aplicação do método WARIMAX-GARCH Neural a uma série temporal medida a cada meia hora de uma série de medidas de deslocamento de um bloco de barragem é descrita. Para fins de comparação, o modelo ARIMA-GARCH convencional também foi aplicado ao mesmo conjunto de dados.

3.1 Série Temporal do Deslocamento

Uma série temporal de deslocamento físico de um bloco da barragem da Usina Hidrelétrica de Itaipu é modelada devido às suas propriedades de relevância e estatísticas. Os 2023 dados correspondem a observações que datam de 28 de outubro de 2005 à 12 de maio de 2011. As 1993 observações iniciais são usadas para treinamento dentro da amostra e, as últimas 30, são usadas para testes fora da amostra para o modelo testado. O teste de raiz unitária *Dikey-Fuller* Aumentado rejeitou fortemente a não estacionariedade, ao nível de 1% de significância, para a série transformada com a aplicação do logaritmo, bem como para a segunda diferença desta última.




Figura 1: Série Temporal de Deslocamento.

Por conseguinte, não houveram variáveis exógenas, com correlação linear entre a série do deslocamento, disponíveis para serem usados num sistema convencional ARIMAX-GARCH. Isso sugere que um modelo ARIMAX-GARCH pode ser um modelo plausível a ser adotado. O diagnóstico dos resíduos para a validação estatística foram realizados o teste da raiz unitária com Dickey-Fuller aumentado, testes de Ljung-Box e Durbin-Watson para autocorrelações de primeira ordem, bem como os gráficos da ACF e FACP (Função Parcial de Auto-correlação), teste BDS para detectar correlações não lineares da série e testes ARCH para a variância residual incondicionalmente constante (Hamilton, 1994). Todos esses testes estatísticos foram realizados utilizando o software EViews 8.

3.2 O Modelo ARIMAX-GARCH

Dada a amostra de treinamento y_t ($t = 1, \dots, 1993$) da série temporal subjacente, o modelo ARIMAX-GARCH que melhor se ajusta aos dados é o modelo ARIMAX-GARCH (2,1,18) (1,1). Todas as estimativas de seus parâmetros foram estatisticamente significativas. O método da máxima verossimilhança foi usado na estimação dos parâmetros do modelo ARIMA-GARCH (2, 1, 18) (1,1). Na Figura 2, o teste Ljung-Box (Q-Stat) sugere que não havia nenhuma estrutura autodependência linear, dentro da amostra, para os resíduos quadráticos padronizados, a 1% de significância, até o lag 24. Além disso, a estatística Durbin-Watson de 2.325354 que sugere que não há autocorrelação

de primeira ordem entre os res duos ordin rios padronizados.

Particularmente, a autodepend ncia linear e quadr tica, presente anteriormente nos res duos de previs o, foram modeladas adequadamente pelo modelo GARCH especificado a seguir. A sele o do modelo entre todos os modelos ARIMA-

GARCH plaus veis identificados foi determinada pela compara o dos desempenhos de previs o de cada modelo candidato medida por: erro absoluto percentual (APE), Erro Absoluto M dio Percentual (MAPE), M dia do erro absoluto (MAE) e R^2 .

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob*
		1 -0.006	-0.006	0.0764	
		2 0.019	0.019	0.7846	
		3 -0.008	-0.008	0.9234	
		4 -0.035	-0.035	3.3450	
		5 -0.008	-0.008	3.4792	0.062
		6 0.005	0.006	3.5240	0.172
		7 0.033	0.032	5.6513	0.130
		8 -0.030	-0.032	7.4988	0.112
		9 -0.004	-0.006	7.5294	0.184
		10 -0.004	-0.002	7.5635	0.272
		11 0.007	0.009	7.6548	0.364
		12 0.048	0.047	12.289	0.139
		13 -0.020	-0.021	13.076	0.159
		14 0.036	0.033	15.686	0.109
		15 0.016	0.021	16.207	0.134
		16 -0.011	-0.010	16.469	0.171
		17 0.009	0.008	16.626	0.217
		18 0.010	0.012	16.832	0.265
		19 0.018	0.017	17.464	0.292
		20 -0.023	-0.019	18.488	0.296
		21 0.019	0.016	19.236	0.315
		22 0.011	0.014	19.459	0.364
		23 -0.033	-0.031	21.608	0.304
		24 0.006	0.001	21.675	0.358

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob*
		1 0.027	0.027	1.4287	0.232
		2 -0.009	-0.010	1.6085	0.447
		3 -0.023	-0.023	2.6849	0.443
		4 -0.019	-0.018	3.4378	0.487
		5 -0.010	-0.009	3.6385	0.603
		6 -0.000	-0.001	3.6386	0.725
		7 -0.027	-0.028	5.1151	0.646
		8 0.009	0.009	5.2669	0.729
		9 -0.015	-0.016	5.6974	0.770
		10 -0.013	-0.013	6.0247	0.813
		11 0.004	0.004	6.0564	0.870
		12 0.047	0.046	10.520	0.570
		13 0.090	0.087	26.893	0.013
		14 -0.012	-0.017	27.188	0.018
		15 0.012	0.017	27.478	0.025
		16 0.047	0.051	31.850	0.010
		17 0.018	0.019	32.473	0.013
		18 0.005	0.007	32.522	0.019
		19 0.024	0.029	33.708	0.020
		20 0.010	0.016	33.896	0.027
		21 0.045	0.047	37.971	0.013
		22 -0.012	-0.007	38.251	0.017
		23 -0.019	-0.012	38.974	0.020
		24 -0.011	-0.010	39.215	0.026

Figura 2: Fun o de Auto-correla o (FAC) e FACP dos Res duos ordin rios padronizados e dos res duos quadr ticos padronizados, respectivamente.

3.3 O Modelo WARIMAX-GARCH Neural

A decomposi o Wavelet de n vel 2 foi obtida pela amostra de treino da s rie do deslocamento horizontal do bloco. A componente Wavelet com a base ortonormal db40 (onde, db40   descrito em (Daubechies, 1988)) pode ser visto na Figura 3.

Sabe-se que $y_t = \tilde{y}_{A_2,t} + \tilde{y}_{D_2,t} + \tilde{y}_{D_3,t} + \varepsilon$ ($t = 1, \dots, 1993$), onde: ε   visto como um vetor nulo (i.e., $\varepsilon = 0$). No passo 2 do m todo WARIMAX-GARCH Neural, cada uma das tr s componentes $\tilde{y}_{A_2,t}$, $\tilde{y}_{D_2,t}$ e $\tilde{y}_{D_3,t}$ foram modeladas usando uma RNA, gerando as sequ ncias de previs es para o seu n vel, denotadas por: $\hat{y}_{A_2,t}$, $\hat{y}_{D_2,t}$ e $\hat{y}_{D_3,t}$ ($t = 1994, \dots, 2023$). Adotou-se um horizonte de previs o $h = 30$, com 30 passos a frente (isso equivale a 30 instantes de previs o). Todos

os par metros estimados pelos tr s modelos foram estatisticamente significativos, ao n vel de 1%.

No passo 3, as tr s componentes Wavelet completadas (denotadas por $\tilde{y}_{A_2,t,C}$, $\tilde{y}_{D_2,t,C}$ e $\tilde{y}_{D_3,t,C}$, ou equivalentemente, x_1, x_2 e x_3) consistem de vari veis ex genas Wavelet geradas a partir da pr pria s rie temporal. Conforme mencionado, as referidas s o facilmente obtidas pelo completamento das componentes Wavelet com previs es geradas fora da amostra no passo 2. Algebricamente, isso significa que:

1. $x_{1,t} = \tilde{y}_{A_2,t,C} := \left((\tilde{y}_{A_2,t})_{t=1}^{1993} ; (\hat{y}_{A_2,t})_{t=1994}^{2023} \right)$;
2. $x_{2,t} = \tilde{y}_{D_2,t,C} := \left((\tilde{y}_{D_2,t})_{t=1}^{1993} ; (\hat{y}_{D_2,t})_{t=1994}^{2023} \right)$;
3. $x_{3,t} = \tilde{y}_{D_3,t,C} := \left((\tilde{y}_{D_3,t})_{t=1}^{1993} ; (\hat{y}_{D_3,t})_{t=1994}^{2023} \right)$.




Figura 3: Componentes Wavelet da s rie de deslocamento de um bloco de barragem.

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob*	
		1	0.027	0.027	1.4512	0.228
		2	-0.009	-0.010	1.6154	0.446
		3	-0.023	-0.023	2.7118	0.438
		4	-0.020	-0.018	3.4776	0.481
		5	-0.010	-0.010	3.6825	0.596
		6	-0.001	-0.001	3.6834	0.719
		7	-0.027	-0.028	5.1793	0.638
		8	0.008	0.009	5.3173	0.723
		9	-0.015	-0.016	5.7579	0.764
		10	-0.013	-0.014	6.0999	0.807
		11	0.004	0.004	6.1314	0.864
		12	0.047	0.045	10.493	0.573
		13	0.091	0.088	26.965	0.013
		14	-0.012	-0.017	27.269	0.018
		15	0.012	0.017	27.550	0.025
		16	0.046	0.051	31.867	0.010
		17	0.017	0.019	32.478	0.013
		18	0.005	0.007	32.522	0.019
		19	0.024	0.029	33.687	0.020
		20	0.010	0.016	33.875	0.027
		21	0.045	0.046	37.903	0.013
		22	-0.012	-0.007	38.178	0.017
		23	-0.019	-0.012	38.914	0.020
		24	-0.011	-0.010	39.158	0.026

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	0.004	0.004	0.0343	0.853
		2	0.008	0.008	0.2130	0.899
		3	-0.002	-0.002	0.2233	0.974
		4	-0.000	-0.000	0.2235	0.994
		5	-0.003	-0.003	0.2396	0.999
		6	0.001	0.001	0.2433	1.000
		7	-0.003	-0.003	0.2594	1.000
		8	-0.000	-0.000	0.2599	1.000
		9	-0.003	-0.003	0.2763	1.000
		10	0.000	0.000	0.2768	1.000
		11	-0.002	-0.002	0.2922	1.000
		12	0.001	0.001	0.2931	1.000
		13	-0.003	-0.003	0.3097	1.000
		14	0.000	0.000	0.3103	1.000
		15	-0.003	-0.002	0.3261	1.000
		16	0.001	0.001	0.3311	1.000
		17	-0.003	-0.003	0.3476	1.000
		18	-0.000	-0.000	0.3481	1.000
		19	-0.002	-0.002	0.3637	1.000
		20	0.000	0.000	0.3640	1.000
		21	-0.003	-0.003	0.3810	1.000
		22	-0.000	-0.000	0.3811	1.000
		23	-0.003	-0.003	0.3986	1.000
		24	-0.001	-0.001	0.4002	1.000

Figura 4: FAC e FACP dos Res duos ordin rios padronizados e dos res duos quadr ticos padronizados, respectivamente.

No passo 4, usando as vari veis ex genas $x_{i,t}$ ($i = 1, 2, 3$), o modelo WARIMAX-GARCH Neural foi ajustado e depois usado para gerar previs  es de 30 passos   frente em rela   o ao n vel e   vari ncia da s rie hist rica. A fun   o WARIMAX que melhor modelou a s rie   dada por:

$$\nabla^3 \left(\hat{f}_{A_2}(t) \right) = \hat{f}_{A_2}(t-1) \times 1.491942 - \hat{f}_{A_2}(t-2) \times 1.214282 + \hat{f}_{A_2}(t-3) \times 0.804555 + \hat{f}_{A_2}(t-5) \times 1.184911 + \hat{f}_{A_2}(t-6) \times 0.549937 + \hat{e}_{A_2}(t-1) \times 0.115114 - \hat{e}_{A_2}(t-2) \times 0.046410 - \hat{e}_{A_2}(t-3) \times 0.590304 - \hat{e}_{A_2}(t-4) \times 0.887668 + 0.657 \times \sigma_{A_2,t}^2. \quad (4)$$

$$\hat{\sigma}_{A_2,t}^2 = 9.85 \times 10^{-9} + 0.265391 \times (\hat{e}_{A_2}(t-1))^2 + 0.703556 \times \hat{\sigma}_{A_2,t-1}^2. \quad (5)$$

A Figura 4 mostra que a FAC e a FACP (até o lag 24) dos resíduos ordinários e dos resíduos quadráticos padronizados, respectivamente, para o modelo WARIMAX-GARCH Neural. Note que para todos os lags até 24, a FAC e a FACP estão dentro dos intervalos de confiança de 99%, sugerindo que estes valores são todos não-significativos. A estatística Durbin-Watson foi 2.026328 confirmando a ausência de autocorrelação de primeira ordem de nos resíduos.

3.4 Comparativos de Desempenhos das Previsões

A Tabela apresentada na Figura 5 mostra as estatísticas MAPE e MAE para dados dentro e fora da amostra e os desempenhos de previsão do modelo ARIMA-GARCH e do modelo WARIMAX-GARCH Neural. Em particular, o método WARIMAX-GARCH Neural produziu grandes melhorias em performances de fora da amostra de previsão com MAPE de 0.220% e 0.0349 de MAE contra 0.794% de MAPE e MAE de 0.166 para o modelo ARIMA-GARCH. Em outras palavras, a metodologia WARIMAX-GARCH Neural melhor modelou a dinâmica da série temporal a que se refere e produziu previsões melhores do que o modelo ARIMA-GARCH convencional.

A Figura 6 mostra o gráfico do erro percentual absoluto (APE) calculado para as previsões fora da amostra em cada passo à frente, para ambos os modelos. Enquanto os erros de previsão do modelo ARIMA-GARCH mostraram uma tendência positiva (crescimento de pouco menos de 1% a cerca de 2.5%) o método proposto WARIMAX-GARCH Neural mostraram flutuações abaixo da linha 0.5%, com o aumento do horizonte de previsão.

MÉTODO	MAPE		MAE	
	Dentro da amostra	Fora da amostra	Dentro da amostra	Fora da amostra
ARIMA-GARCH	0.325%	0.794%	0.00487	0.1272
WARIMAX-GARCH Neural	0.152%	0.220%	0.0227	0.0349

Figura 5: Performance das previsões para os modelos ARIMA-GARCH e WARIMAX-GARCH Neural para dados dentro e fora da amostra de teste.




Figura 6: Comparação da Evolução temporal do erro percentual absoluto para WARIMAX-GARCH- Neural e ARIMA-GARCH.

Em termos do coeficiente R^2 , os resultados mostram que WARIMAX-GARCH Neural explicou aproximadamente 99.94% da variação na série de deslocamento do bloco da barragem da Itaipu enquanto o ARIMA-GARCH explicou apenas 7.44%.

4 Conclusões

Neste trabalho, propôs-se uma metodologia de previsão causal chamado de método WARIMAX-GARCH Neural, que incorpora variáveis Wavelet como variáveis exógenas implicando em melhorias substanciais em relação aos modelos de previsão ARIMA-GARCH. As componentes incorporadas Wavelet têm propriedades estatísticas apropriadas para ser justificado o seu uso. Por exemplo, os componentes de detalhe são sempre um processo estacionário de segunda ordem e também sempre presente variância condicional (volatilidade) (ver, por exemplo, (Engle, 1982)) - que permite efeitos não lineares serem contabilizados no modelo final. Além disso, a componente de aproximação Wavelet sempre pode ser modelada por um ARIMA-GARCH sempre que a sua série de tempo original também for capaz.

Nota-se, também, que as componentes Wavelet apresentam sempre uma forte correlação com a variável de resposta y_t ($t = 1, \dots, T$), uma vez que são obtidas a partir do último. Por fim, o método proposto foi aplicado a uma série temporal diária de deslocamento de um bloco da barragem principal da Usina de Itaipu. Os resultados comparados contra o modelo ARIMA-GARCH convencional mostrou que o método WARIMAX-GARCH Neural não só produziu previsões com melhores performances, de acordo com as estatísticas MAPE e MAE para dados dentro e fora da amostra apontadas na Tabela vista na Figura 5, mas também pode ser operacionalizado de uma forma relativamente simples.

Referências

Binacional, I. (2009). *Usina Hidrelétrica de Itaipu: Aspectos de Engenharia*, Foz do

Iguaçu-Brasil: Realização Diretoria Técnica da Itaipu Binacional-Coordenação Geral Superintendência de Engenharia da Itaipu Binacional. CDU.

- Bollerslev, T. (1986). Generalized autoregressive conditional heteroskedasticity, *Journal of econometrics* **31**(3): 307–327.
- Box, G. E. and Tiao, G. C. (1975). Intervention analysis with applications to economic and environmental problems, *Journal of the American Statistical association* **70**(349): 70–79.
- Daubechies, I. (1988). Orthonormal bases of compactly supported wavelets, *Communications on pure and applied mathematics* **41**(7): 909–996.
- Engle, R. F. (1982). Autoregressive conditional heteroscedasticity with estimates of the variance of united kingdom inflation, *Econometrica: Journal of the Econometric Society* pp. 987–1007.
- Hamilton, J. D. (1994). *Time series analysis*, Vol. 2, Princeton university press Princeton.
- Haykin, S. S. (2001). *Redes neurais*, Bookman.
- Júnior, L. A. T. (2013). *Combinação SSA-Wavelet de métodos preditivos com ajuste numérico MINIMAX, na geração de previsões e de cenários*, PhD thesis, PUC-Rio.
- Kubrusly, C. and Levan, N. (2006). Abstract wavelets generated by hilbert space shift operators, *Advances in Mathematical Sciences and Applications* **16**(2): 643.
- Levan, N. and Kubrusly, C. S. (2003). A wavelet time-shift-detail decomposition, *Mathematics and computers in simulation* **63**(2): 73–78.
- Mallat, S. (2008). *A wavelet tour of signal processing: the sparse way*, Academic press.